

ニューラルネットワークによる 軸箱加速度からの台車枠応力予測について

小柳 勝敬* 三宮 大輝 (JR 西日本)

榎田 耕伸 加藤 祐貴 秋山 裕喜 相田 健一郎 瀧上 唯夫 (鉄道総研)

Prediction of bogie frame stress from axle boxes acceleration by neural network

Katsuhiro Koyanagi*, Daiki Sannomiya, (West Japan Railway Company)

Yasunobu Makita, Yuki Kato, Yuki Akiyama, Ken-ichiro Aida, Tadao Takigami,

(Railway Technical Research Institute)

We are developing a method for predicting stress of bogie frames by using measured acceleration of axle boxes of bogies. In this paper, we propose a new prediction method by using neural network. We conducted running tests on a commercial line and calculated the predicted stresses of bogie frames by the proposed method. A comparison between the predicted stresses obtained by the proposed method and the measured stresses was made to verify the validity of the proposed method.

キーワード：軸箱，台車枠，加速度，応力，ニューラルネットワーク，予測手法
(Axle box, Bogie frame, Acceleration, Stress, Neural network, Prediction method)

1. はじめに

鉄道車両用台車では、主に新製時に台車枠の強度を確認するため、JIS E 4207: 2019⁽¹⁾、JIS E 4208-1: 2021⁽²⁾および JIS E 4208-2: 2021⁽³⁾に基づき静荷重試験や走行試験が行われている。このうち走行試験では、台車枠各部に発生する応力（以下「動的応力」という。）の測定を行うが、測定にはひずみゲージを台車枠の各測定箇所貼付ける必要があり、多大な時間やコストを要するため、それらの低減が求められている。

これに対し、著者らはひずみゲージを用いることなく台車枠各部の動的応力（以下「台車枠応力」という。）を把握する手法の開発に取り組んでいる。これまでに、ひずみゲージよりも取り付けが容易な加速度センサで測定を行う軸箱振動加速度（以下「軸箱加速度」という。）に着目し、軸箱加速度と台車枠応力との間の伝達関数を推定したうえで、伝達関数に予測対象とする走行区間の軸箱加速度を掛け合わせることで台車枠応力を予測する手法を提案した⁽⁴⁾。なお、この手法で用いた伝達関数は、軸箱加速度と台車枠応力との間に線形の伝達特性を有することを前提としていることから、対象とする系が非線形の場合には予測精度の低下が課題となる可能性が考えられる。

そこで本報では、軸箱加速度から台車枠応力を予測する手法の一つとして、対象とする系が非線形の場合にも適用

可能であるニューラルネットワーク（以下「NN」という。）による手法を新たに提案する。近郊形電車の走行試験で測定した軸箱加速度および台車枠応力を用いて、入力（軸箱加速度）から出力（台車枠応力）を時系列データとして予測する NN モデルを作成し、予測応力の妥当性を評価した結果を示す。

2. ニューラルネットワークモデル

ニューラルネットワーク (NN) とは、脳神経回路の一部を模した数理モデル、または、パーセプトロンを複数組み合わせ合わせたものの総称とされている。パーセプトロンの簡易モデルを図 1 に、NN の簡易モデルを図 2 に、それぞれ示す。

入力から出力までの一連の手順をパーセプトロンと呼び、入力および出力の各構成要素をニューロンと呼ぶ。NN では、入力層、隠れ層、出力層が存在し、各層間および隠れ層内部は、複数のパーセプトロンの組み合わせで構成されている。本報告では、NN のうち、時間遅延を設定し、時系列データの履歴 (順序) を考慮した学習を可能とする Time Delay Neural Network⁽⁵⁾を用いて、入力（軸箱加速度）から出力（台車枠応力）を時系列データとして予測した。




図 1 パーセプトロンの簡易モデル




図 2 ニューラルネットワークの簡易モデル

3. ニューラルネットワークモデルの適用方法

NN モデルにより軸箱加速度から台車枠応力を予測する手法の具体的適用方法を図 3 に示す。主な手順は次の 2 つである。

〈3・1〉 NN モデルの作成 (Step1)

ここでは、区間 A で軸箱加速度および台車枠応力を取得する走行試験を実施する。この区間 A では、学習用データとする区間 A-1、検証用データとする区間 A-2 に割り振り、それぞれ NN モデルの学習と妥当性の検証に用いる。ここで、検証用データは学習用データとは別区間のデータであり、NN モデルの汎用性の確保を目的としてモデルの評価に

使用するデータである。

まず、走行試験で得られたデータを基に、①学習が行われる。この段階では、学習用データとする区間 A-1 において、台車各部の応力が軸箱加速度から予測される。予測された応力（以下「予測応力」という。）は実測応力と照合され、これらの誤差が最小となるように各ニューロンの重み等を修正のうえ、再度予測応力が算出される。この手順を複数回行うことで「繰り返し学習」が行われる。その後、最終的に区間 A-1 において最適な NN モデルが作成される。

次に、過学習の防止を目的とする②検証の段階では、検証用データとする区間 A-2 に対して、区間 A-1 での最適な NN モデルを適用し、それにより算出された予測応力と区間 A-2 の実測応力が比較検証されることで、誤差が算出される。

以上、①学習、②検証ののち、③設定の変更（レイヤー数、ユニット数等）が行われ、再度、①学習が行われる。

①～③を複数回繰り返し、検証用データとした区間 A-2 において算出される誤差が最小となるモデルを本報告における最適モデルとする。

〈3・2〉 NN モデルの適用 (Step2)

Step2 では、Step1 で作成した最適モデルを別の線区に適用する。理想的な運用例として、区間 A とは別に応力を評価したい区間とする区間 B において走行試験を行い、軸箱加速度のみを取得し、これに Step1 で作成した NN モデルを適用することで、予測応力を算出する。

なお、本来の活用シナリオでは応力を実測することなく予測することを想定しているが、本報告では、予測応力の妥当性評価のため、区間 B でも台車枠応力を測定した。

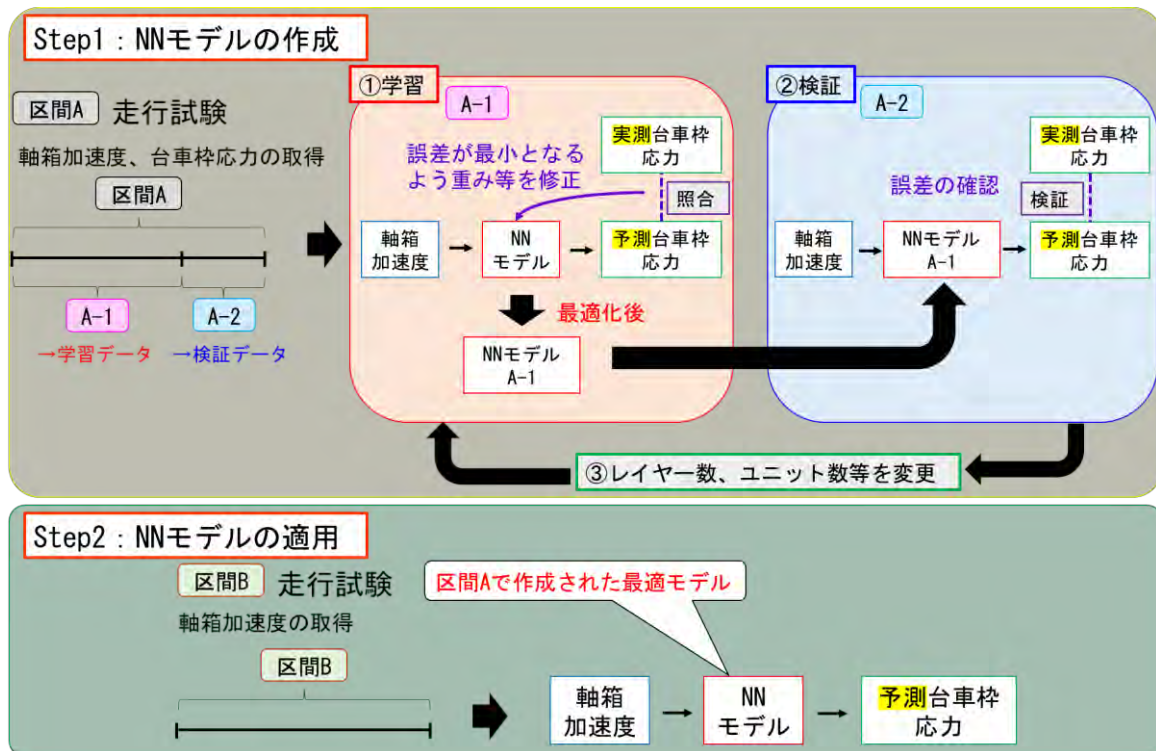


図 3 NN モデルによる台車枠応力予測手法の適用方法

4. 走行試験

〈4・1〉 概要

営業線区で近郊形電車による走行試験を実施した。測定対象台車は、主電動機付き台車であり、走行時の軸箱加速度、台車枠応力等を取得した。なお、データ収録時のサンプリング周波数は 3000 Hz である。

〈4・2〉 測定点

軸箱加速度および台車枠応力測定点を図 4 に示す。軸箱加速度は各部位の軸箱において、上下、左右、前後の 3 方向を取得した。台車枠応力測定点は、側ばり、横ばり等とした。





図 4 軸箱加速度および台車枠応力測定点

5. 応力予測結果および考察


〈5・1〉 各台車枠応力測定点の応力予測結果

応力予測データに供した図 3 に示す区間 B における各台車枠応力測定点の実測応力と NN モデルによる予測応力(以下「NN 予測応力」という。)の時刻歴応答、およびパワースペクトル密度(以下「PSD」という。)を図 5~図 7 に、実測応力最大値および最小値と NN 予測応力との誤差率を表 1 に、それぞれ示す。なお、誤差率は NN 予測応力から実測応力を減じた値と実測応力との割合で表される。

本報では伝達関数による予測結果例として示した前報⁽⁴⁾の誤差率(約 20%)よりも小さくなるような予測精度の実現を目標とした。




(a) 時刻歴応答




(b) 応力 PSD

図 5 測定点 G1 の予測結果




(a) 時刻歴応答




(b) 応力 PSD


図 6 測定点 G2 の予測結果



(a) 時刻歴応答



(b) 時刻歴応答 (実測応力最小値観測時刻付近の拡大)



(c) 応力 PSD

図 7 測定点 G3 の予測結果

表 1 実測応力最大値・最小値と NN 予測応力との誤差率

測定点	最大値 誤差率 [%]	最小値 誤差率 [%]
G1	-5	3
G2	-19	-11
G3	-27	-66

注記 誤差率は実測応力に対する誤差の割合で表される。

測定点 G1 について、図 5(a)より、NN 予測応力は実測応力の波形の傾向を概ね再現できていること、図 5(b)より、110 Hz 程度以下の周波数帯域では、NN 予測応力と実測応力の PSD はほぼ一致していることを確認した。また、表 1 より、実測応力最大値および最小値の誤差率は $\pm 5\%$ 以下であり、目標とする予測精度が得られたことを確認した。

測定点 G2 についても同様に、図 6(a)より、NN 予測応力は実測応力の波形の傾向を概ね再現できていること、図 6(b)より、110 Hz 程度以下の周波数帯域では、NN 予測応力と実測応力の PSD はほぼ一致していることを確認した。表 1 より、実測応力最大値および最小値の誤差率は $\pm 20\%$ 未満であり、目標とする予測精度を満たした。

測定点 G3 について、図 7(a)より、NN 予測応力は実測応力の波形の傾向を概ね再現できたが、実測応力に比べて予測応力が小さい傾向であった。また、図 7(b)より、実測応力の最小値において、NN 予測応力は実測応力の低周波成分を再現できておらず、表 1 のとおり、実測応力最小値は目標とする誤差率を超過した。一方で、図 7(a)の 44 s および 60 s 付近において、実測応力よりも NN 予測応力が過大に出力されており、図 7(c)より、数 Hz 帯において、実測応力よりも NN 予測応力が大きい傾向がみられた。これは、軸箱加速度の低周波成分に対する出力が実際よりも大きくなるモデルが作成されたためと考えられる。

(5.2) 汎用性の検証


NN モデルを区間 B 以外にも適用するとともに、車両の進行方向による影響を検証した。本節では、単線の同一区間の進行方向上りおよび下り走行時における測定点 G1 の予測結果を対象とする。なお、進行方向上りのデータを学習データとし、NN モデルは作成されている。測定点 G1 の実測応力と NN 予測応力の時刻歴応答を図 8 に、実測応力と NN 予測応力との誤差率を表 2 に、それぞれ示す。

図 8(a)は進行方向上り走行時の時刻歴応答であるが、表 2 より、実測応力最大値および最小値と NN 予測応力との誤差率は $\pm 10\%$ 未満であり、目標とする予測精度が得られたことを確認した。一方で、図 8(b)は進行方向下り走行時の時刻歴応答であり、図 8(a)と同様、NN 予測応力は実測応力の波形の傾向を概ね再現できているが、表 2 より、誤差率は上り走行時よりも大きくなった。これより、ここで着目した応力測定点では、車両の進行方向の違いが予測精度に影響を及ぼすことを確認した。


6. まとめ

軸箱加速度から台車枠応力を予測する手法の構築を目的とし、走行試験のデータを用いて、ニューラルネットワークにより入力（軸箱加速度）から出力（台車枠応力）を時系列データとして予測するモデルを作成し、台車枠応力予測精度の妥当性を評価した。得られた結果等を次に示す。

- (1) 軸箱加速度と台車枠各部の応力との関係をニューラルネットワークに学習させた非線形性を含む伝達特性を有する予測モデルにより、軸箱加速度から台車枠応力



(a) 進行方向上り



(b) 進行方向下り

図 8 測定点 G1 の予測結果（進行方向の違いによる影響）

表 2 測定点 G1 の実測応力最大値・最小値と NN 予測応力との誤差率（予測範囲拡大）

進行方向	最大値 誤差率 [%]	最小値 誤差率 [%]
上り	-2	7
下り	-16	35

注記 誤差率は実測応力に対する誤差の割合で表される。

- を予測する手法を開発した。
- (2) 走行試験データによる検証の結果、測定点によっては実測応力の波形の傾向を再現可能であること、また、著大値に対する誤差率が、目標とした 20 %以下になることを確認した。
- (3) 同一区間の上りおよび下り走行時の著大値に対する誤差率を比較した結果、車両の進行方向の違いが予測精度に影響を及ぼすことを確認した。

文 献

- (1) JIS E 4207 : 2019 「鉄道車両—台車—台車枠強度設計通則」
- (2) JIS E 4208-1 : 2021 「鉄道車両—台車—強度試験—第 1 部：静荷重試験方法」
- (3) JIS E 4208-2 : 2021 「鉄道車両—台車—強度試験—第 2 部：走行試験方法」
- (4) 横田耕伸・他：「軸箱加速度を活用した台車枠応力の予測手法」、日本機械学会 第 28 回鉄道技術連合シンポジウム講演論文集、No.21-72、講演番号 SS2-2-6 (2021)
- (5) Waibel, Alexander, et al : "Phoneme recognition using time-delay neural networks", IEEE transactions on acoustics, speech, and signal processing, Vol.37, No.3, pp.328-339 (1989)